

DOI: 10.19783/j.cnki.pspc.241293

新能源不确定性表征方法及关键技术问题 研究现状、挑战及展望

李夫刚¹, 李夫海², 琚承乾³, 陈仕军¹, 杨亚东⁴, 丁凡⁵

(1. 四川大学, 四川 成都 610065; 2. 国网信产集团北京中电普华信息技术公司, 北京 102211; 3. 华能澜沧江水电
有限责任公司, 云南 昆明 650214; 4. 国网石嘴山供电公司, 宁夏 石嘴山 750001;
5. 国网宁东电力有限公司, 宁夏 灵武 750001)

摘要: 随着清洁能源的大规模发展, 风、光等清洁能源的接入日益增多, 水、风、光多能互补系统的应用越来越广泛。如何对水、风、光等能源的出力变化以及负荷增长的不确定性进行建模, 给电网的安全、经济运行调度和规划带来了许多挑战。采用基于传统概率建模和人工智能技术对不确定性进行量化是推动新型电力系统不确定优化技术发展的关键。针对现有新能源不确定性表征问题, 全面综述了相关研究。首先阐述了不确定性量化的概念, 新能源与气象耦合的关系及量化方法。其次从研究对象和数学问题两个方面阐述了电力系统新能源不确定性的基本概念, 回顾了现有的研究方法、评估指标和典型场景的应用现状。最后总结了当前研究中所存在的问题, 并展望了未来的发展趋势和挑战, 旨在为相关研究提供参考与借鉴。

关键词: 碳达峰碳中和; 不确定性表征; 传统概率建模; 深度学习

Methods for characterizing renewable energy uncertainty and key technical issues: research status, challenges, and prospects

LI Fugang¹, LI Fuhai², JU Chengqian³, CHEN Shijun¹, YANG Yadong⁴, DING Fan⁵

(1. Sichuan University, Chengdu 610065, China; 2. SGICT Group Beijing China-Power Information Technology Co., Ltd., Beijing 102211, China; 3. Huaneng Lancang River Hydropower Co., Ltd., Kunming 650214, China; 4. State Grid Shizuishan Power Supply Company, Shizuishan 750001, China; 5. State Grid Ningxia Electric Power Co., Ltd., Lingwu 750001, China)

Abstract: With the large-scale development of clean energy, the integration of wind and solar power is increasing, and multi-energy complementary systems involving hydro, wind, and solar power are becoming more widely applied. However, accurately modeling the uncertainty in the output of these energy sources, as well as load growth, poses significant challenges for the safe and economical operation, dispatch, and planning of power grids. Characterizing this uncertainty using traditional probabilistic modeling and artificial intelligence technologies is crucial for advancing uncertainty-based optimization techniques in modern power systems. This paper presents a comprehensive review of the current research on renewable energy uncertainty characterization. First, it introduces the concept of uncertainty quantification and explores the coupling relationship between renewable energy sources and meteorological factors, along with relevant quantification methods. It then discusses the basic concepts of renewable energy uncertainty in power systems from the perspectives of research objects and mathematical problems, reviewing existing research methods, assessment indicators, and the application of typical scenarios. Finally, it summarizes the current research challenges and discusses future development trends and directions, aiming to provide references and insights for related studies.

This work is supported by the National Key Research and Development Program of China (No. 2018YFB0905204).

Key words: carbon peaking and carbon neutrality; uncertainty characterization; traditional probabilistic modeling; deep learning

基金项目: 国家重点研发计划项目资助(2018YFB0905204); 四川省科技计划项目资助(22ZDYF2707)

0 引言

在“双碳”目标成为国家战略的时代背景下,随着能源转型,清洁能源上网比例不断增加^[1]。可再生能源(风电/光伏)因其低成本和零污染等显著优势,在全球范围内得到了大力推广和应用^[2]。据国际能源署报道,2024年全球可再生能源容量增长近50%^[3]。到2028年,风光使用规模将实现翻倍,预计其共同份额将达到25%^[4]。新能源(风/光)属于间歇性可再生能源(intermittent renewable energy sources, IRES),其发电具有不可预测性和波动性,这为电力系统的稳定供应和有效管理带来了巨大的挑战和不确定性^[5]。随着新能源并网规模飞速增长,因灵活性需求所导致的弃电风险,以及高比例清洁能源系统在安全运行方面面临的挑战日益凸显^[6]。如何准确描述风光出力不确定性成为克服这些挑战的关键。因此,量化新能源不确定性对于系统运营商评估发电损失的可能性并减轻此类风险至关重要。

电力系统领域针对新能源不确定性建模的方法主要包括鲁棒优化、区间优化、机会约束和场景法^[7-8]。鲁棒优化通过不确定性因素的边界信息构建不确定性集合,并利用概率信息进行优化^[9]。区间优化使用区间数来描述系统中的不确定性参数,从而建立区间优化模型。这种方法不需要假设不确定参数的精确概率分布,因此在处理新能源出力不确定性时具有独特优势。机会约束允许在一定的概率水平下不满足某些约束条件,从而可以在面对不确定性时保持一定的灵活性^[10]。场景法降低了大量离散场景的计算复杂度,有效提升了优化问题的效率。与不确定性集合相比,离散场景在电力系统不确定性优化中能够提供更可靠、更稳定的决策解^[11]。随着人工智能技术的迅速发展以及电力物联网的大规模应用,为可再生能源不确定性量化研究带来了新的机遇,也将成为推动能源革命的关键技术支撑。

在此背景下,本文综述了不确定性量化的概念、新能源出力不确定性的基础理论以及新能源不确定性建模方法等研究。首先,全面概述了不确定性的相关概念,涵盖了不确定性的定义,以及新能源与气象之间的耦合关系及其量化方法。同时,本文从新能源出力的不确定性入手,对研究对象及相关数学问题进行了详细阐述。重点分析并归纳了风电和光伏的不确定性建模及其核心技术问题。其次,针对电力系统中的风电和光伏不确定性建模技术,全面综述了传统的时序概率建模、场景分析和深度学习技术3大方面的现有研究方法及其优缺点,并介绍了不同技术的性能评估指标。此外,探讨了现

有技术在实际应用中的现状及面临的问题。最后,总结了电力系统中可再生能源不确定性表征方法研究所面临的问题,并对未来的研究方向及可能遇到的挑战进行了展望。

1 不确定性量化概述

1.1 不确定度的定义

不确定度是指测量值或预测值与实际值之间的差异程度,表明了在进行测量或预测时固有的误差范围。它反映了由于各种不确定因素(如测量误差、环境变化等)所引起的结果的不确定性^[12]。

不确定度的定义和分析在科学研究、工程技术和决策制定中具有重要意义,因为它有助于评估测量和预测结果的可靠性和精度。不确定性与风险紧密相关,在风险度量中起着重要作用。不确定性可以分为两类:固有不确定性(alcatory uncertainty)是自然界固有的,由系统内在的随机性所决定,无法通过更多信息或分析来降低。认知不确定性(epistemic uncertainty)则源于对现象理解不足或信息不完整,这种不确定性可以通过增加知识进行进一步研究,或获取更多数据来降低^[13]。

在工程领域,不确定性通常被定义为由所收集信息的内在缺陷而导致的知识不完备性^[14]。在电力系统中,不确定性的准确建模和分析对确保系统的安全、稳定和经济运行尤为重要。其主要来源包括可再生能源出力的波动性、负荷需求的变化以及设备故障等^[15-16]。通过采用先进的统计方法和人工智能技术,可更好地应对这些不确定性,提升系统的运行效率和稳定性。

1.2 新能源与气象的耦合关系

1.2.1 新能源与气象的耦合机理

新能源的不确定性与气象因素之间的耦合机理是一个复杂且重要的研究,尤其在风光能源发电领域。以下概述了新能源不确定性与气象因素之间的耦合关系。

1) 光伏发电与气象因素的耦合:光伏发电功率受多元气象因素的影响,包括辐照度、组件温度、环境温度和风速等。光伏发电功率与气象影响因子之间存在多重耦合的非线性关系,这使得仅使用线性相关系数和灰色关联度来衡量气象影响因子的作用程度难以获得满意效果。因此,信息熵理论和互信息等方法被用来量化光伏发电功率与气象影响因子之间的动态关联关系。

2) 风电与气象因素的耦合:风电功率与风速、温度、辐照度、相对湿度等气象因素密切相关。这些气象因素的不确定性对风电功率的预测精度提出

了挑战。

3) 风光荷一体化预测中的耦合: 在风光荷一体化预测中, 风电功率、光伏发电功率和负荷与气象因素之间存在一定的互动耦合关系。考虑这些耦合关系可以提升预测精度。另外, 气象敏感型综合能源负荷(如电、冷、热等)具有较强的随机性、不确定性及耦合转化关系。

4) 中长期时序场景生成中的耦合: 在高比例可再生能源电力系统中, 源荷功率在气象的影响下耦合程度增加。基于典型源荷耦合模式的中长期时序场景生成方法可以提高场景在气象方面的可解释性, 并减小源荷数据匹配样本少对中长期源荷耦合场景生成的影响。

1.2.2 量化新能源与气象的耦合关系的方法

1) 互信息熵(mutual information entropy, MIE)方法: 基于 MIE 的相关性衡量指标, 计算光伏功率与各气象因素间的互信息熵, 以实现高维气象数据降维处理。这种方法可筛选出与光伏功率变化最相关的气象因素, 从而提高预测的准确性。

2) 长短期记忆(long-short term memory, LSTM)神经网络: 结合 MIE 方法筛选出相似日样本, 使用 LSTM 神经网络预测模型建立气象因素与光伏出力之间的映射关系。此方法可捕捉时间序列数据中的长期依赖关系, 适用于短期光伏功率预测。

3) 信息熵理论: 利用信息熵理论对光伏发电功率与气象影响因子之间的动态关联关系进行量化研究。通过定义光伏发电功率与气象影响因子的互信息, 并选择等间距法近似计算其值, 可以对不同天气类型下的互信息值进行比较。

4) 灰色关联分析方法: 采用灰色关联分析方法对气象影响因子作用程度进行趋势分析。这种方法可以消除不同变量数值差异的影响, 并考虑极值信息对关联程度的作用, 从而衡量光伏发电功率与气象影响因子之间的关联程度。通过散点图和相关系数对光伏发电功率与多元气象影响因子的相关性进行分析, 并讨论不同天气类型对相关性的影响。

2 新能源出力不确定性理论

2.1 风电不确定性数学模型

风电机组的出力稳定性面临着多种挑战, 其中, 风速作为风电发电的关键因素, 其变化往往呈现出不可预测的特征, 导致风电机组的输出功率存在较大的波动。Rayleigh 分布模型是一种统计分布模型, 常用于描述某些特定类型的随机变量的概率

分布。Rayleigh 分布适用于风速数据分布峰值较高的风场。Rayleigh 分布的概率密度函数 $f_R(v, \sigma)$ 及累积分布函数 $F_R(v, \sigma)$ 如式(1)、式(2)所示。

$$f_R(v, \sigma) = \frac{v}{\sigma^2} \exp\left(-\frac{1}{2}\left(\frac{v}{\sigma}\right)^2\right) \quad (1)$$

Rayleigh 分布的累积分布表达式为

$$F_R(v, \sigma) = 1 - \exp\left(-\frac{1}{2}\left(\frac{v}{\sigma}\right)^2\right) \quad (2)$$

式中: v 表示风速; σ 为尺寸参数, 代表风速分布的宽带。风速分布越宽、波动范围越大, σ 的取值越大; 风速分布越集中、越均匀, σ 的取值越小。建立风速模型后, 可得出风机有功出力 and 风速的公式为

$$P_{wt}^* = \begin{cases} 0, & 0 \leq v < v_{ci}, v > v_{co} \\ \frac{1}{2} \rho A C_p \left(\frac{v^3}{v_r^3}\right) P_r, & v_{ci} \leq v < v_r \\ P_r, & v_r \leq v < v_{co} \end{cases} \quad (3)$$

式中: P_{wt}^* 为风机的实际输出功率; P_r 为风机的额定功率; v_r 为额定风速; v_{ci} 为切入风速; v_{co} 为切出风速; ρ 为空气密度; A 为风轮扫过的面积; C_p 为风能利用系数; v 为当前风速。

2.2 光伏不确定模型

光伏发电系统由多个光伏组件组装而成, 这些组件的核心是太阳能电池片。太阳能电池片的性能直接影响到光伏系统的发电能力, 光伏发电的效率和产量依赖于太阳辐射的强度, 使用概率密度函数 $f(I_t | \mu_t, \sigma_t)$ 来描述太阳辐射度的分布, 其中 μ_t 、 σ_t 分别为对数正态分布的均值和标准差。具体可描述为

$$f(I_t | \mu_t, \sigma_t) = \frac{1}{I_t \sigma_t \sqrt{2\pi}} \exp\left[-\frac{(\ln I_t - \mu_t)^2}{2\sigma_t^2}\right] \quad (4)$$

$$\begin{cases} \mu_t = \ln\left(\frac{m_t^2}{\sqrt{n_t + m_t^2}}\right) \\ \sigma_t = \sqrt{\ln\left(\frac{n_t}{m_t^2} + 1\right)} \end{cases} \quad (5)$$

式中: I_t 为 t 时段太阳辐射度; m_t 、 n_t 为对数正态分布随机变量的均值和方差。 t 时段出力与太阳辐射度的相关性可近似表示为

$$W_{s,t} = \begin{cases} \frac{I_t^2}{I_{std} r_c} W_{sr} & 0 < I_t \leq r_c \\ \frac{I_t}{I_{std}} W_{sr} & I_t > r_c \end{cases} \quad (6)$$

式中: I_{std} 为标况下太阳辐射度; r_c 为某特定情况下太阳辐射度; W_{sr} 为额定输出功率; $W_{s,t}$ 为实际输出功率。

2.3 功率偏差置信风险分析

风光发电固有的不确定性和波动性使得功率预测面临诸多挑战。预测误差可能导致实际出力的高估或低估, 从而对电力市场的用电量平衡产生深远的影响。在这种背景下, 引入机会约束的方法能够精确地评估风光发电的高估和低估风险。通过采用不同色调区域的方式, 来表示不确定性置信区间中的不同置信水平, 使决策者能够更直观地了解各类风险的可信程度。这种方法的实施不仅有助于优化调度效率, 还能为电力系统运营提供更为科学的决策依据, 如图 1 所示。

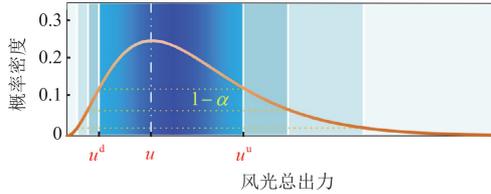


图 1 风光高估/低估出力概率分布图

Fig. 1 Wind/solar overestimated and underestimated output probability distribution

$$\begin{cases} \Pr\{u^d(u, \alpha) \leq u \leq u^u(u, \alpha)\} = 1 - \alpha \\ 0 \leq \alpha \leq 1 \end{cases} \quad (7)$$

式中: \Pr 表示概率; $u^u(u, \alpha)$ 和 $u^d(u, \alpha)$ 分别表示其不确定性置信区间的置信上、下限; u 为不确定性变量及其预测值; $1 - \alpha$ 为置信水平, α 越小, 置信水平越高。

2.3.1 风电出力高估/低估置信风险

由于风力的随机性及预测方法的局限性, 实际发电量可能低于或高于最初的预测值。风力发电的预测准确性受到多重因素的影响, 具体的高估或低估情况亟需通过综合的概率分布模型进行深入分析, 而这种高估或低估的概率分布见图 2。

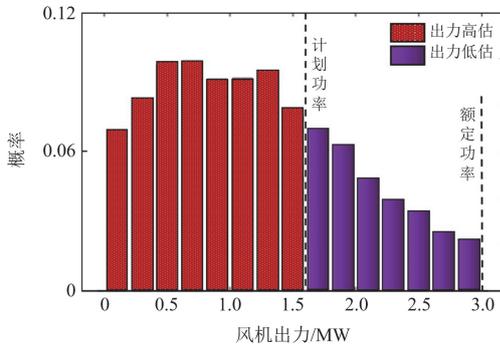


图 2 风电高估/低估出力概率分布图

Fig. 2 Wind power overestimated and underestimated output probability distribution

由式(3)可得, t 时段风电机组出力置信上限和置信下限 $P_{w,t}^u(\alpha)$ 、 $P_{w,t}^d(\alpha)$ 分别为^[17-18]

$$P_{w,t}^u(\alpha) = \begin{cases} P_r & v_t^u \geq v_r \\ \frac{(v_t^u)^3 - v_{ci}^3}{v_r^3 - v_{ci}^3} P_r & v_t^u < v_r \end{cases} \quad (8)$$

$$P_{w,t}^d(\alpha) = \begin{cases} 0 & v_t^d < v_{ci} \\ \frac{(v_t^d)^3 - v_{ci}^3}{v_r^3 - v_{ci}^3} P_r & v_t^d \geq v_{ci} \end{cases} \quad (9)$$

式中: v_t^u 、 v_t^d 分别为 t 时段风速置信区间的置信上、下限。

2.3.2 光伏出力高估/低估置信风险

太阳辐射度的不确定性可用对数正态分布来描述, 因对数正态分布的累积分布函数和概率密度函数相对复杂。可用出力直方图量化功率偏差风险, 其能够有效地评估光伏电站出力的高估和低估功率偏差所带来的置信风险^[19]。光伏电站可用出力直方图如图 3 所示。

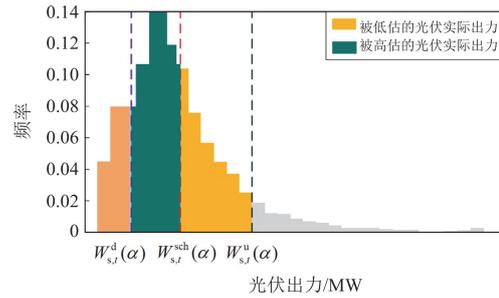


图 3 光伏高估/低估出力概率分布图

Fig. 3 Solar power overestimated and underestimated output probability distribution

图 3 中, t 时段光伏电站的预估出力值为 $W_{s,t}^{sch}(\alpha)$ 、置信上限为 $W_{s,t}^u(\alpha)$ 、置信下限为 $W_{s,t}^d(\alpha)$, 可推导出

$$W_{s,t}^u(\alpha) = \begin{cases} \frac{(I_t^u)^2}{I_{std} r_c} W_{sr} & 0 < I_t^u \leq r_c \\ \frac{I_t^u}{I_{std}} W_{sr} & I_t^u > r_c \end{cases} \quad (10)$$

$$W_{s,t}^d(\alpha) = \begin{cases} \frac{(I_t^d)^2}{I_{std} r_c} W_{sr} & 0 < I_t^d \leq r_c \\ \frac{I_t^d}{I_{std}} W_{sr} & I_t^d > r_c \end{cases} \quad (11)$$

式中: I_t^u 、 I_t^d 分别为 t 时段太阳辐射度置信区间的置信上、下限。

综上所述, 可得 t 时段光伏电站在置信水平 $1-\alpha$ 下出力高估、低估功率偏差置信风险 $d_{s,t}^H(\alpha)$ 、 $d_{s,t}^L(\alpha)$ 分别为

$$d_{s,t}^H(\alpha) = R_f [W_{s,t}^d(\alpha) \leq W_{s,t} \leq W_{s,t}^{\text{sch}}(\alpha)] \times \{W_{s,t}^{\text{sch}}(\alpha) - E[W_{s,t}^d(\alpha) \leq W_{s,t} \leq W_{s,t}^{\text{sch}}(\alpha)]\} \quad (12)$$

$$d_{s,t}^L(\alpha) = R_f [W_{s,t}^{\text{sch}}(\alpha) \leq W_{s,t} \leq W_{s,t}^u(\alpha)] \times \{E[W_{s,t}^{\text{sch}}(\alpha) \leq W_{s,t} \leq W_{s,t}^u(\alpha)] - W_{s,t}^{\text{sch}}(\alpha)\} \quad (13)$$

式中: R_f 、 E 分别表示在置信水平 $1-\alpha$ 下光伏电站实际出力被高估/低估的相对频率、期望值。

3 新能源不确定性建模方法

风能和光伏发电过程中的不确定性量化表征研究大致可以划分为两类: 场景模拟与不确定性集合。这两种方法在处理发电过程中的随机性和不确定性时各具独特优势。场景模拟归属于随机优化的框架, 其核心在于通过大量的原始数据来获取准确的概率分布信息。基于此, 本文将新能源出力不确定性研究方法归结为: 基于传统时序概率建模的场景分析技术、基于深度学习的的海不确定性建模技术两方面。

3.1 基于传统时序概率建模的场景分析技术

新能源发电出力波动并非完全随机, 可通过分析时间序列数据来识别其潜在的模式或趋势。因此, 在场景分析的过程中, 需要深入研究时间序列的建模方法。场景法是一种创新性的分析工具, 它通过利用历史的风能和光能发电数据, 生成未来可能的风力和光伏发电场景。这一方法的核心在于对生成的大量场景进行有效地精简和筛选, 应用场景削减技术能够将众多场景浓缩为少数具有代表性的典型场景, 这些典型场景不仅反映了可再生能源出力的波动特性, 还有助于相关决策者更清晰地理解潜在风险和变化趋势。

3.1.1 场景生成技术

场景生成技术是一种依据目标对象的统计属性, 采用特定的抽样策略, 创建出反映该对象不确定性特质的一系列情景方法。风光发电场景构建方法可细分为 3 种主要类型, 每种类型均具有特定的应用场景与技术背景。第一类方法是直接对风电和光伏的概率分布特性进行抽样, 这种方法能够直观地反映出风光发电的自然能量波动特征。第二类方法侧重于对风电和光伏出力的统计特性进行数学建模, 以期在更为系统化的框架内捕捉到发电的不确定性。第三类方法进一步结合了预测误差, 对光伏和风电的概率分布特性进行抽样, 这种方法尤其适用于需要考虑短期变动的场景生成。在实现场景生

成的技术手段方面, 涵盖了多种具体技术, 包括蒙特卡洛和拉丁超立方抽样、自回归移动平均误差模型、场景树构建方法及概率预测方法等。这些技术的使用, 使得风光发电场景的构建不仅具备了较高的灵活性, 还增强了其实用性, 有助于在各种情况下快速生成切合实际的电力调度场景。这些方法的核心思想是将包含随机变量的随机优化问题转化为凸随机优化问题, 并求解其期望值模型为

$$\min_{x \in X} E_p f(\omega, x) = \int_{\Omega} f(\omega, x) P d\omega \quad (14)$$

式中: $x \in X$ 表示决策变量 x 属于决策变量集合 X ; P 为 ω 在 Ω 空间的概率测度, 属于概率空间 $P(\Omega)$; E_p 为关于概率测度 P 的期望。

1) 蒙特卡洛方法

蒙特卡洛方法是一种通过随机抽样和统计分析来模拟和分析复杂系统的方法, 在场景生成中具有重要应用^[20-21]。通过蒙特卡洛抽样生成场景的核心内容包括随机抽样和模型运行。随机抽样: 从每个输入变量的概率分布中抽取大量数据点, 通常通过伪随机数生成器来实现。在设定的标准概率范围内, 采用类似于轮盘赌的随机选择方法来确定每个时间点的预测误差及其相关概率。模型运行: 将每组抽样数据输入到系统模型中, 运行模型模拟系统的行为和输出。这些输出可能包括电力生产量、系统成本、可靠性指标等。

2) 场景树法

场景树法是一种广泛应用于创建时间序列场景的技术, 其核心理念是, 为每个时间点生成场景时, 均以前一个时间点场景的结果作为基础进行抽样。在构建未来场景时, 充分考虑了时间的连续性与相关性^[22]。值得注意的是, 场景树的数量不仅受各时间断面抽样数量的影响, 还与时间长度有着密切的关系, 因此在生成大量场景树时, 这一因素不可忽略。此外, 场景树法生成的序列通常没有充分考虑时序相关性, 可能导致生成场景序列出现较大的波动。当抽样结果过于复杂或时间跨度较长时, 会产生“维数灾”问题, 即场景空间的维度急剧增加, 导致计算和分析变得极为困难^[23]。因此, 在应用场景树法时, 需谨慎选择抽样策略和时间范围, 以避免此类问题的出现。

3) 马尔科夫链法

马尔科夫链法是一种常见且有效的场景生成方法。其利用马尔科夫链的状态转移性质, 通过给定的转移概率来模拟和预测系统的未来状态^[24]。由于可再生能源的输出在时间上展现出一定程度的相似性, 因此可将其视作马尔科夫链模型^[25]。在模拟风

电和光伏出力的时序场景时, 能够很好地捕捉到时序相关性^[26]。在构建长期能源场景模型的过程中, 可以运用一种先进的马尔科夫链模型。这种模型通过对季节与气候特征进行详细分类, 构建出在不同条件下状态转换的概率矩阵。尽管马尔科夫链模型能够捕捉时间序列之间的相关性, 但在表达超短期场景的时间序列特性方面存在局限, 因此它更适合用于生成短期而非超短期的能源场景。

3.1.2 场景缩减技术

在现代电力系统的优化研究中, 场景缩减技术的应用显得尤为重要。其主要目的在于从海量的光伏和风电场景中筛选出具有代表性的场景, 以此提高优化模型的求解精度, 并有效降低计算量。面对日益复杂的可再生能源系统, 大量的场景数据使得对于目标函数的分析更加困难^[19]。因此, 合理的场景缩减方法成为解决这一问题的关键。场景缩减的方法可以分为经验缩减法和数学缩减法两大类。经验缩减法, 如典型日法, 主要依赖专家的经验来选择具有代表性的典型日, 这种方法的优点在于操作简单, 但可能会受到主观因素的影响, 导致选择的场景不够全面。而数学缩减法则通过更加客观和系统化的方式, 将初始场景通过合并形成典型场景, 常见的技术包括后向消减法、前向消减法、场景树构建法及聚类分析等。这些方法旨在通过规则性和规律性的挖掘, 有效地提炼出能代表全局特征的少量典型场景。

3.2 基于深度学习的确定性建模技术

针对上述研究现状, 深度学习中的生成技术展现出了其独特的优势。这类技术能够在处理复杂数据时, 通过模拟和生成不同的场景集, 有效地扩展实验和研究的可能性, 从而为规划提供更为全面的视角。

3.2.1 生成对抗网络

生成对抗网络(generative adversarial networks, GAN)是一种深度学习模型, 它通过对真实数据集进行训练, 以拟合模型, 进而隐式地学习数据的概率分布^[27]。这种模型利用深度学习来识别和表达数据的内在模式和特征。在 GAN 结构中的生成器和判别器之间实现了一种“纳什均衡”状态^[28]。这种博弈过程可以通过式(15)来描述, 它概括了 GAN 网络在进行极大极小化博弈时的模型框架。

$$\min_G \max_D V(G, D) = E_{x \sim p_x} [D(x)] - E_{z \sim p_z} [D(G(z))] \quad (15)$$

式中: $E(\cdot)$ 表示期望值; $x \sim p_x$ 为真实数据 x 服从真实分布 p_x ; $z \sim p_z$ 为噪声数据 z 服从噪声分布 p_z ; $D(x)$ 表示真实数据 x 在判别器中判别为真的概率值; $D(G(z))$ 为生成数据 $G(z)$ 在判别器中判别为

真的概率值。

Wasserstein 生成对抗网络是在传统 GAN 的基础上改进而来, 它引入了 Wasserstein 距离来衡量真实数据和生成数据之间的差异, 取代了原先的 Jensen-Shannon(JS)距离。这种改进有效缓解了 GAN 在训练过程中常见的梯度消失和训练不稳定的问题^[29]。根据文献[30], Wasserstein 距离定义为

$$W(p_r, p_g) = \frac{1}{Q} \sup_{\|f\|_2 \leq Q} \{E_{x \sim p_r} [f(x)] - E_{x \sim p_g} [f(x)]\} \quad (16)$$

式中: $W(p_r, p_g)$ 是真实数据分布 p_r 和生成数据分布 p_g 之间的 Wasserstein 距离; \sup 为最小上界; $\|f\|_2 \leq Q$ 为函数 f 满足 Q -Lipschitz 连续, 其导函数绝对值上界 Q ; Q 为 Lipschitz 常数; L 为 Lipschitz 条件。

GAN 在电力系统中的应用主要涉及新能源发电场景的生成。通过训练生成器和判别器两个模块, GAN 能够学习新能源发电数据的分布, 并生成新的数据样本, 以处理新能源发电的不确定性问题。然而, GAN 训练过程中会出现梯度消失或过拟合等问题, 需要通过调整网络结构和目标函数来解决。

3.2.2 条件生成对抗网络

条件生成对抗网络(conditional generative adversarial networks, CGAN)是一种对 GAN 进行改进的模型, 结构如图 4 显示。CGAN 通过引入条件信息, 结合了监督学习和无监督学习的技术^[31]。类似于 GAN, CGAN 也采用了生成器和判别器之间的对抗性博弈机制。因此, 生成器与判别器可由式(17)和式(18)列出, L_G 和 L_D 分别为生成器和判别器的损失函数。

$$L_G = -E_{z \sim p_z} [D(G(z|y))] \quad (17)$$

$$L_D = -E_{z \sim p_z} [D(x|y)] + E_{z \sim p_z} [D(G(z|y))] \quad (18)$$

CGAN 通过引入条件信息生成特定条件下的新能源发电场景。例如, 以风/光电站的空间位置作为条件信息, 学习可再生能源出力的时间-空间相关性, 生成风/光场景。CGAN 在电力系统中的应用可以提高场景生成的准确性和适用性。

3.2.3 深度卷积生成对抗网络

深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN)是对 GAN 架构进行的一系列优化。这种架构上的改进不仅显著增强了网络的稳定性, 还有效提升了生成样本的质量。此外, 该改进还提高了模型的收敛速率, 使得训练过程更加高效, 以此提升了生成数据的质量, 从而生成高质量的合成样本^[32-33]。图 5 展示了其结构示意图。风电光伏的出力曲线包含了多样动

态特征，DCGAN 的特性使其特别适合捕捉这类曲线中的动态元素^[34-35]。

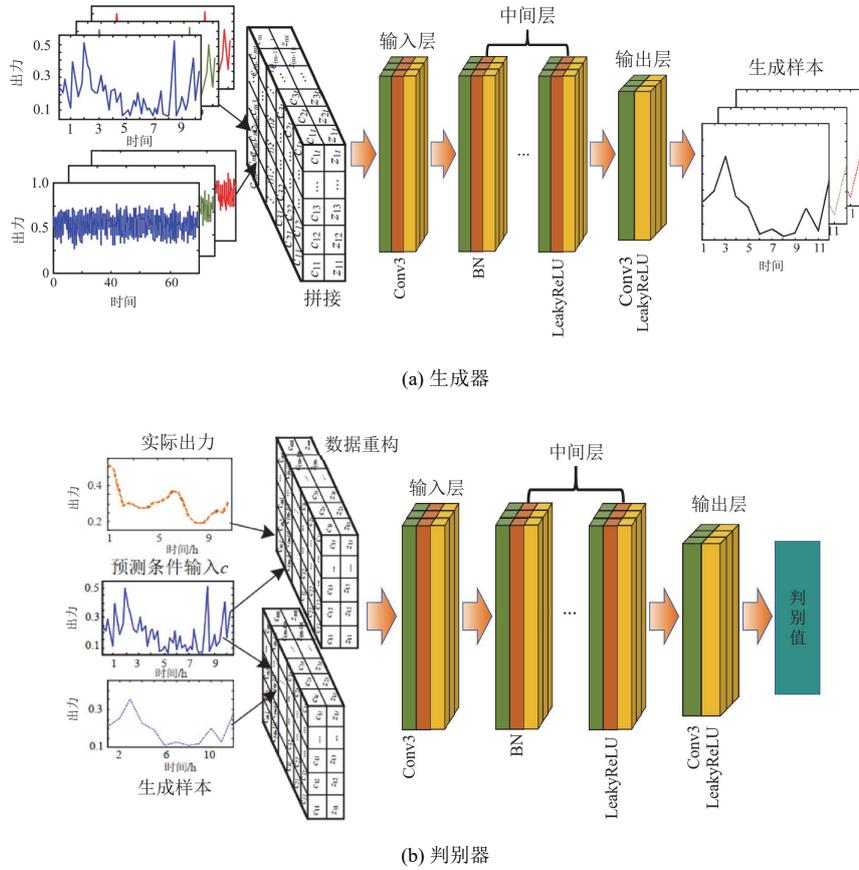


图 4 CGAN 的结构示意图

Fig. 4 Structure diagram of CGAN

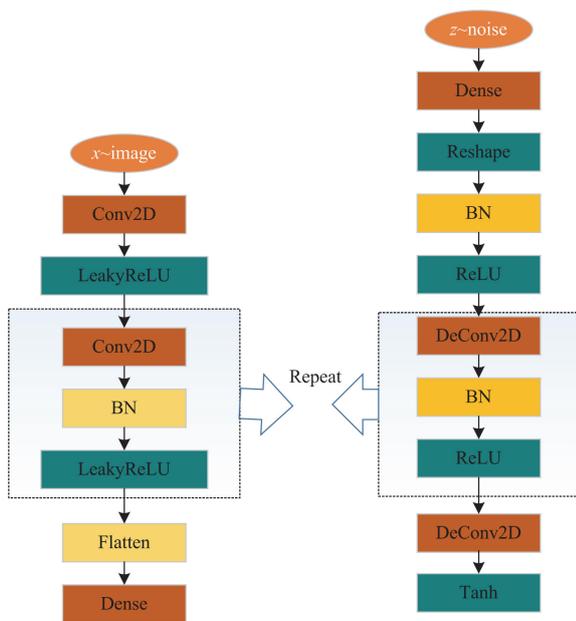


图 5 DCGAN 结构示意图

Fig. 5 Structure diagram of DCGAN

DCGAN 采用卷积神经网络作为生成器与判别器的网络结构，训练过程更稳定，生成样本多样性更丰富。在电力系统中，DCGAN 可用于生成风光发电功率场景，通过引入缩放点注意力机制，将深度卷积网络替换成时序卷积网络，构建时序生成对抗网络。

3.2.4 变分自编码器

变分自编码器(variational autoencoder, VAE)是自编码器的一种发展形式。VAE 作为一种高效的数据生成模型，其网络结构主要由两个关键组件组成，包括编码器和解码器。编码器的作用是将输入数据映射到潜在空间，而解码器则负责从潜在空间中重构出与原始输入相似的输出^[36-37]。在此框架下，为了量化识别模型与真实后验分布之间的拟合程度，VAE 利用 KL 散度(Kullback-Leibler divergence)来进行相应的测量^[38]。因此，VAE 的损失函数 $L(\varphi, \theta, x)$ 的完整计算公式为

$$L(\varphi, \theta, x) = \text{KL} \left\{ [q_\varphi(\delta|x)], [p_\theta(\delta|x)] \right\} - E_{q_\varphi(\delta|x)} \left\{ \log [p_\theta(\delta|x)] \right\} \quad (19)$$

式中: $q_\phi(\delta|x)$ 为编码器; $p_\theta(\delta|x)$ 为解码器; δ 为隐变量; 前项表示隐含变量的概率分布与先验分布之间的相似程度, 二者的概率分布越接近, KL 散度值越小; 后项表示重构样本与原始样本之间的误差。

在电力系统中, VAE 可以用于生成与原始数据类似但不完全相同的数据, 如图像、文本、音频等, 也可以用于数据增广和异常检测。VAE 与 CGAN 的联合结构可以通过 VAE 提取天气信息的特征, 并将相关特征作为 CGAN 的条件信息, 生成特定天气条件下的光伏出力场景。

3.2.5 改进变分自编码器

传统的 VAE 虽然在一定程度上提升了生成效果, 但在处理一些特定类型的数据集时, 其局限性逐渐显露^[28]。在此背景下, 文献[32]提出了一种新型的 VAE 模型, 该模型具备无监督标签功能, 能够自动识别和区分不同的数据类型, 从而为数据生成提供更为智能的支持, 结构如图 6 所示。通过自动化的标签识别, 不仅减轻了人工处理的负担, 还在很大程度上降低因主观判断所带来的偏差。

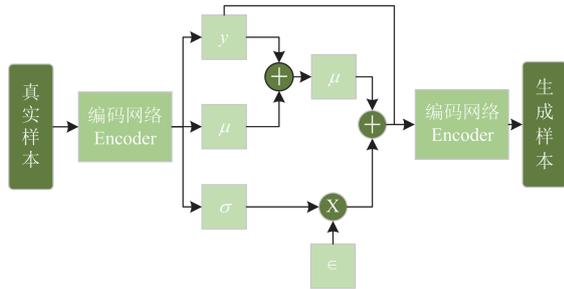


图 6 改进 VAE 结构示意图

Fig. 6 Improved VAE structure diagram

与标准 VAE 不同, 改进的网络结构在编码网络与解码网络之间引入了一个标签值 y 。与 VAE 的目标相类似, 改进网络的目标函数可看作后验分布 $p_\theta(\delta, x, y)$ 与先验分布 $q_\phi(\delta, x, y)$ 之间的 KL 散度。

$$L(\phi, \theta) = \text{KL}(p_\theta(\delta, x, y) \| q_\phi(\delta, x, y)) \quad (20)$$

与前述 VAE 损失函数推导类似, 经替换并整理化简可以得到

$$\text{KL}(p_\theta(\delta, y|x) \| q_\phi(\delta, y)) = \iint p_\theta(\delta, y|x) \ln \frac{p_\theta(\delta, y|x)}{q_\phi(\delta, y)} d\delta dy = \quad (21)$$

$$E_{y \sim p(y)} \left[\text{KL}(p_\theta(\delta|x, y) \| q_\phi(\delta|y)) + \ln \frac{p(y)}{q(y)} \right]$$

式中: $\text{KL}(p_\theta(\delta, y|x) \| q_\phi(\delta, y))$ 表示隐变量 δ 的先验分布与后验分布之间的差异; $p(y)$ 表示标签值 y 的

后验分布; $q(y)$ 表示标签值 y 的先验分布。若对标签值分布无先验要求, 可认为 $p(y) = q(y)$, 则第二项为 0。公式为

$$L = E_{x \sim p(x)} [E_{(\delta, y) \sim p(\delta, y|x)} [-\ln q(x|\delta, y)]] + E_{y \sim p(y)} [\text{KL}(p(\delta|x, y) \| q(\delta|y))] \quad (22)$$

在电力系统中, 改进 VAE 可以用于增强数据, 提高模型的泛化能力和故障诊断的准确性。改进的 VAE 模型, 如 InfoVAE, 通过引入信息瓶颈来提高模型的泛化能力。这些改进模型可以用于生成更加多样化和真实的新能源发电场景, 或者用于电力系统的异常检测, 通过识别数据中的异常模式来提高系统的安全性和可靠性。

4 不确定性表征方法的应用研究现状

4.1 基于传统概率建模方法的处理技术

针对风光不确定性的研究, 采用统计学方法建立出力场景模型显得尤为重要。将风电和光伏出力的不确定性视为一种统计模型。通过统计学手段能够有效地捕捉风电和光伏能量输出中的不确定性, 并生成相应的出力场景, 为电力系统的调度和规划提供重要支持。文献[39]采取分段处理的方式来对预测误差进行建模, 基于联合正态分布, 通过抽样生成了所需场景。文献[40]提出了一种基于 Wasserstein 距离度量的最佳分位数方法生成典型情景集, 其综合考虑了能源之间的相关性。此外, 文献[41-43]运用了拉丁超立方抽样技术对风电出力预测过程中存在的误差概率分布进行分层抽样。现有的统计模型大多集中于描述单一特征时序场景的不确定性, 这使得其在处理特定地点或系统的整体输出时表现出明显的局限性^[44]。值得注意的是, 风电场及其集群的误差分布往往不符合正态分布, 而呈现出其他复杂的分布特征, 意味着传统模型在捕捉可再生能源出力不确定性方面的建模能力不足^[45]。同时, 多风电场场景的生成问题涉及深层的时间与空间相关性, 这一复杂性需要进一步的研究来进行准确建模和预测^[46]。因此, 亟需深入探索新方法以更好地应对这些复杂的时间-空间相关性, 提升模型的准确性和实用性。目前, 分析这种相关性的方法主要可以分为两种类型: 第一种是通过构建多元变量的联合概率分布进行相关性分析; 第二种是借助 Copula 函数来提取相关性信息。文献[47]通过物理机制解析模型, 对风速的联合分布进行了预测, 从而生成了具有相关性的多风电场出力场景。然而, 单一的 Copula 函数不足以全面捕捉变量之间的相关性。文献[48]提出了一种混合 Copula 函数模型,

对两个风场之间的相关性进行深入分析,结果表明其拟合的误差较小,具有较高的准确性。因此,准确描述风电功率数据的相关性,须选择合适的 Copula 函数,以确保研究结果的有效性和可靠性^[49]。

场景分析法作为应对不确定性的重要工具,能够明确地展示不确定因素的概率特征,建立随机规划模型。目前,场景分析法主要依赖于基于概率模型的方法,这些方法主要包括马尔科夫链法^[50]、场景树生成法及时间序列法^[51]。在场景生成研究方面,文献[52]通过采用自回归滑动平均模型创建了多样化的场景数据。文献[53]利用 Wasserstein 距离方法有效地构建了场景集。文献[54]创新性地将蒙特卡洛抽样与轮盘赌相结合,对风电出力 and 碳交易价格预测误差的概率分布进行了有效的抽样,从而生成了相应的场景。文献[55]则运用自回归滑动平均模型对历史风速数据进行建模,生成准确的风电出力场景。在建立相关性模型方面, Copula 函数法备受青睐。文献[56-58]均运用 Copula 函数构建了相关性模型,经抽样技术生成用于分析的典型场景。大规模的抽样场景集将导致计算效率降低。因此,开展了很多场景消减算法的研究^[59-60]。在场景缩减研究方面,现有研究主要依赖于多种聚类算法。文献[61]采用同步回代消除法进行场景缩减;文献[58]对快进选择法进行了改进,提出了一种资源簇前向选择法,显著降低了计算的复杂性;文献[62]使用后向缩减法最大化样本的拟合精度,从而生成具有代表性的典型场景;文献[63]比较了不同的场景缩减技术在电力系统随机规划中的应用效果,结果显示前向消减法的效果最佳;文献[64]在后向消减法中引入了一个新的成本函数,其在随机规划问题中的应用效果得到了显著提升。这种方法通过优化成本函数改进后向消减法的性能;文献[65]则通过抽样技术对风电、光伏发电和电力负荷的预测误差概率分布进行研究,然后利用后向消减法对这些场景进行了筛选和缩减。这些场景分析技术被成功应用于离网/微电网风、光、蓄、储协同调度中,为电力系统能源管理及规划提供了重要参考。文献[66]提出了一种基于云模型的模糊均值聚类算法(fuzzy C-means method, FCM),该算法能够高效、精准地提取出具有代表性的典型场景。文献[67]提出了一种启发式搜索方法,相较于传统的前向和后向缩减方法,该新方法在处理速度上得到明显提升。然而,这几种算法在应对大规模数据消减问题时伸缩性较差,导致生成模型的复杂度增加,限制了生成场景的多样性。因此,如何提升这些算法在处理大规模问题上的适用性和效率,仍是当前研究需要重点关注

的问题。

4.2 人工智能技术

传统模型不仅处理复杂的非线性关系困难,而且对训练数据量的要求较高,使得其在实际应用中受到了一定的限制。深度学习的特性能够完全依赖数据驱动,具备无监督和自主学习的能力,这些优势使其在电力系统中的应用价值愈发明显。文献[68]提出了一种基于条件变分自编码器的风光出力随机场景生成方法,该方法采用无监督学习方式来获取数据样本的概率分布。文献[45,69]运用 CGAN 技术探索风电出力在时间和空间上的相关性,生成精准的可再生能源日前场景集。文献[34]提出利用 GAN 来学习可再生能源出力的时间-空间相关性,该方法旨在深入捕捉可再生能源出力的复杂特性。文献[70]提出了一种基于数据驱动的新能源场景生成方法,把自注意力机制和生成对抗网络判别器结合,构建混合深度学习模型,突显了新能源出力时序特性,提升了非线性拟合能力。文献[71]提出一种新颖的算法,该算法基于 GAN 反向训练输入噪声进一步优化生成对抗网络的性能。文献[72]为提高模型捕获风光电站之间的时空相关性特征的能力,引入梯度惩罚策略,进一步提出了改进的生成对抗网络模型。文献[73]提出了基于残差卷积自编码器的风光荷场景生成方法,将多通道卷积与自编码器融合形成多通道卷积自编码器,通过添加跨层级调整模块,提高编码器的特征提取能力。文献[46,74-76]采用 WGAN 的方法来进行风光场景的模拟。尽管这种方法能够实现较为稳定的网络性能,但在学习过程中其网络模型的约束性却显得不足。

针对上述不足,文献[77]提出一种基于 CGAN 的多区域风电出力场景生成方法,该方法采用三维卷积网络结构进行设计,避免了非线性相关性特征的问题。该方法无需依赖复杂的概率建模和采样机制,能够自适应地反映资源的随机性与动态性。此外,当前的多源场景生成方法在生成过程中往往忽视了样本中的时空相关性。为了应对这一问题,文献[78]中引入了一种基于改进的 InfoGAN 方法的风光出力场景生成技术,通过融入信息论的概念,提高生成场景的可解释性和灵活性,有效解决了现有方法在时空功率相关性建模方面的不足。文献[79]提出了一个分布式的风力发电场景生成方法,并使用生成对抗网络与强化学习相结合。文献[80]提出了一种新的联邦深度生成学习框架,称为 Fed-LSGAN,通过集成联邦学习和最小二乘生成对抗网络生成可再生场景。另外,当前的研究方法普遍将时空功率统一转换为一维向量进行处理。这种处理方式可简化

数据的运算与分析, 但会使模型无法真实反映原始功率的时空分布关系。因此, 现有方法在处理时空功率时存在明显的局限性, 亟需进行改进, 以提高场景生成的准确性和可靠性。文献[81]利用利用格拉姆角场(Gramian angular fields, GAF)将一维数据转换为二维图像, 采用卷积神经网络(convolutional neural network, CNN)提取时间序列的相关特征, 再用残差神经网络(residual neural network, ResNet)提取与风电功率相关的其他相关数据的特征, 实现网络深度增加及解决退化问题, 对风电不确定性进行充分刻画。在现代计算机视觉领域, 实现高效可靠的场景建模已成为一项关键的研究任务。为此, 文献[82]提出了一种可控场景生成方法, 以提高场景建模的质量和效率。该方法引入了 Transformer 的注意力机制, 以增强场景生成的准确性。文献[83]采用 Transformer 深度学习模型用于风电功率预测, 实验表明该模型在准确性和效率方面均优于卷积神经网络、长短期记忆网络等 4 种深度学习模型。此外, 采用卷积和深度可分离卷积的局部泛化机制, 使得模型在处理不同类型的场景时, 能够保持较高的泛化能力。这种多重机制的有效整合, 显著提升了场景建模的效率和可靠性, 为相关研究提供了新的思路 and 方向。

5 关键问题、技术难点及未来展望

在可再生能源不确定性建模领域, 学习方法的研究尚处于初级阶段。尽管不确定性量化表征的方法已取得了一定的发展, 但仍面临若干亟待解决的问题。针对这些问题, 本文将从以下几个方面进行详细探讨。

1) 模型精确性与计算复杂度的平衡

概率建模方法通常需要较大的抽样规模, 这不仅增加了计算量, 还显著增加了运算复杂度, 给实际应用带来了挑战。虽然简化模型在计算效率上有所提高, 但这种简化往往会导致精确性的下降; 相反, 更为精确的模型通常伴随着较高的计算复杂度, 因此在实际应用中难以得到平衡。现有的建模方法尚未有效解决这一问题, 加之数据不足, 限制了模型在实际应用中的适用性和精确性。

2) 场景分析的逼近精度与运算效率

场景集生成算法的难点在于如何以尽可能少的场景来逼近原随机优化问题的精度。现有的抽样方法虽然基于大数定理, 但初始规模庞大导致计算量巨大。提升场景集对原问题的逼近精度与保持运算效率之间的平衡是一个挑战。现有算法多采用串行搜索方式, 随着场景集规模的增大, 时间复杂度急

剧上升。为了解决抽样场景集规模过大的问题, 提出了场景消减算法。然而, 目前这些算法大多数仍采用串行遍历搜索方式。这种方式的时间复杂度随着场景集规模的增加而急剧增大, 呈现平方指数增长的趋势, 限制了计算效率和处理规模, 进而引发维数灾的问题。

3) 人工智能方法的泛化能力

人工智能方法在处理大量数据时尤为关键, 不仅需要其具备很强的泛化能力, 还要求能够在多样化的环境中进行有效的学习和应用。随着优化调度时段的增加, 涉及的场景集合规模可能会呈现出指数级增长, 这导致对计算资源的需求大大提高, 因此必须不断优化算法和模型结构, 以应对日益增长的计算压力。尤其是在风光发电规模持续扩大的背景下, 算法必须能够适应更大规模的数据集与更复杂的模型。综上所述, 人工智能的广泛应用面临着泛化能力、计算资源需求、模型解释性和算法可扩展性等多重挑战, 这些问题的解决将是推动人工智能技术进一步发展的关键。

4) 多源数据融合, 跨学科交叉与集成

通过融合气象数据、卫星遥感数据、地面观测数据等多源数据, 构建更加准确和鲁棒性更强的不确定性模型。同时, 风光发电不确定性表征涉及气象学、统计学、计算机科学和电力系统等多个学科。未来的研究可以加强多学科的交叉合作, 集成各学科的优势, 推动技术创新和应用。例如, 可以结合气象学的预测模型和统计学的分析方法, 发展更加精确和可靠的不确定性表征技术。

5) 基于海量数据, 迁移建模

在现有的场景生成研究中, 数据集的完整性与质量直接影响研究结果的准确性和有效性。尤其是在新能源领域, 风光场景生成时, 研究人员常常面临同源数据缺失或者数据不完整的困扰。这一问题不仅限制了生成模型的性能, 同时还对后续的分析 and 预测造成了重大影响。此外, 研究中还涉及到非同源数据的使用, 由于这些数据来源不同, 存在显著的异构性, 进一步加大了场景生成的复杂性。面对这些挑战, 通过海量数据进行迁移建模显得尤为关键。迁移建模可有效利用已有数据结构, 减小风光场景生成过程中的不确定性, 提高生成结果的可信度和可用性。与此同时, 数字孪生化场景生成技术的引入, 不仅能够提升理论研究的创新性, 还能将这些研究成果转化为实际应用, 推动理论与实践的紧密结合。因此, 针对新能源场景生成中的数据缺失和异构性问题, 结合先进的迁移建模与数字孪生技术, 为理论研究的实际应用开辟出新的途径。

综上所述,未来的研究方向应当致力于将深度学习与联邦学习方法结合起来,以开发出既具有可解释性又能够实现训练稳定的概率建模方法。这种融合不仅可以提高模型的适用性与整体性能,还能够增强对复杂数据的处理能力,使得研究成果更具实际应用价值。

6) 动态不确定性表征,智能优化与决策

构建动态不确定性表征模型,考虑风光发电输出的时间序列特性和动态变化规律,提供更加实时和灵活的预测与分析工具。

(1) 风光动态不确定性表征

风光动态不确定性表征是指对风力发电和光伏发电系统中随时间变化的不确定性因素进行准确描述和量化。这些不确定性因素可能包括风速的波动、光照强度的变化、天气条件的突变等。动态不确定性表征模型旨在准确捕捉风光发电(风能和太阳能)输出的随机性和波动性。为了实现这一目标,可以采用以下表征方法:对于风力发电,常用的表征方法包括风速概率分布模型、风速时间序列预测等。这些模型能够捕捉风速的随机性和波动性,为后续的优化和决策提供依据。对于光伏发电,光照强度的概率分布模型、云量预测等是常用的表征方法。这些方法能够反映光照强度的变化,从而预测光伏发电的输出功率。根据风光发电的不确定性表征,可以制定更加合理的能源管理策略,提高能源利用效率。

(2) 智能优化算法与决策模型的结合

在风光发电系统中,将动态不确定性表征结果与智能优化算法和决策模型结合,智能优化技术用于解决不确定性因素带来的挑战,可提升电力系统的运行效率和经济性。基于规则的决策模型:根据风光发电系统的特点和运行规则,制定相应的决策策略。例如,在风速低于一定阈值时,启动备用电源或调整风电场的输出功率。基于机器学习的决策模型:通过训练模型可以学习风光发电系统的运行规律和不确定性因素的变化趋势,从而制定更加准确的决策策略。在电力系统优化调度方面:基于风光发电的不确定性预测结果,构建优化调度模型,考虑风光发电的波动性和预测误差,制定合理的发电计划。在市场交易策略制定方面:在电力市场中,利用风光发电的不确定性信息,可以制定更为灵活的市场交易策略,优化资源配置,降低交易风险。例如,基于预测误差的市场出价策略可以提高新能源的市场竞争力。

综上所述,通过构建动态不确定性表征模型,结合智能优化算法和决策模型,将风光发电不确定

性表征结果应用于电力系统优化调度、市场交易策略制定等实际场景,提高电力系统的运行效率和经济性。这不仅有助于实现可再生能源的高效利用,也为电力市场的稳定发展提供了支持。

6 结论

随着新一代电力系统在高比例新能源接入后,其所表现出的多源性和复杂性带来了显著的不确定性特征。面对这种挑战,对电力系统中源与负荷之间的不确定性进行精确建模显得尤为重要,因为这对于系统的安全性、经济运行以及未来的规划都起着关键作用。尤其是在风能和太阳能发电的快速发展背景下,如何有效地表征其不确定性成为保障电力系统安全与可再生能源持续发展的核心技术之一。在风光发电不确定性建模技术方面,目前主要分为两类:传统的时序概率建模方法以及基于深度学习的先进技术。本文详细综述了这些方法的优缺点,以及不同性能评估指标的适用性和有效性。这些建模技术能够有效地量化风光发电的输出不确定性,并且在电力系统的各个方面均有广泛应用,为现代电力系统的稳定性和经济性提供了重要保障。未来的研究应当致力于优化和改进现有的不确定性表征方法,以提高其精度和可靠性,从而更好地支持电力系统的高效运行和可再生能源的广泛应用。同时,学界与业界也亟需总结在可再生能源不确定性表征方法研究中所面临的问题,展望未来的研究方向与挑战,以推动这一领域的发展。

参考文献

- [1] 李晖,刘栋,姚丹阳.面向碳达峰碳中和目标的我国电力系统发展研判[J].中国电机工程学报,2021,41(18):6245-6258.
LI Hui, LIU Dong, YAO Danyang. Analysis and reflection on the development of power system towards the goal of carbon emission peak and carbon neutrality[J]. Proceedings of the CSEE, 2021, 41(18): 6245-6258.
- [2] 方必武,范展滔,王科,等.考虑储能荷电越限的高比例可再生能源系统的源荷储协调优化[J].供用电,2024,41(7):92-98.
FANG Biwu, FAN Zhantao, WANG Ke, et al. Coordinated optimization of source-load-storage for a high-proportion renewable energy system considering the overcharge of energy storage[J]. Distribution & Utilization, 2024, 41(7): 92-98.
- [3] 国家能源局.国家能源局发布2023年全国电力工业统计数据[EB/OL].[2023-12-13].https://www.nea.gov.cn/2023-12/20/c_1310756286.html.

- [4] 国家能源局. 国家能源局关于建立监测预警机制促进风电产业持续健康发展的通知(NEA[2016] 196号)[EB/OL]. [2016-07-18]. http://www.pkulaw.cn/fulltext_form.aspx?Db=alftwotitle&Gid=01b3df025aa3e410bdfb.
- [5] NEGNEVITSKY M, NGUYEN D H, PIEKUTOWSKI M. Risk assessment for power system operation planning with high wind power penetration[J]. IEEE Transactions on Power Systems, 2015, 30(3): 1359-1368.
- [6] 康重庆, 姚良忠. 高比例可再生能源电力系统的关键科学问题与理论研究框架[J]. 电力系统自动化, 2017, 41(9): 1-11.
KANG Chongqing, YAO Liangzhong. Key scientific issues and theoretical research framework for power systems with high proportion of renewable energy[J]. Automation of Electric Power Systems, 2017, 41(9): 1-11.
- [7] 董骁翀, 张姝, 李焯, 等. 电力系统中时序场景生成和约简方法研究综述[J]. 电网技术, 2023, 47(2): 709-721.
DONG Xiaochong, ZHANG Shu, LI Ye, et al. Review of power system temporal scenario generation and reduction methods[J]. Power System Technology, 2023, 47(2): 709-721.
- [8] 张韶华, 王必恒, 石城, 等. 基于分布鲁棒优化的电热综合能源配网系统与氢能源站协同优化[J]. 电测与仪表, 2023, 60(12): 36-43.
ZHANG Shaohua, WANG Biheng, SHI Cheng, et al. Collaborative optimal dispatching of integrated electricity-heat energy distribution network system and hydrogen fueling station based on distributionally robust optimization[J]. Electrical Measurement & Instrumentation, 2023, 60(12): 36-43.
- [9] 蔺伟山, 王小君, 孙庆凯, 等. 不确定性环境下基于深度强化学习的综合能源系统动态调度[J]. 电力系统保护与控制, 2022, 50(18): 50-60.
LIN Weishan, WANG Xiaojun, SUN Qingkai, et al. Dynamic dispatch of an integrated energy system based on deep reinforcement learning in an uncertain environment[J]. Power System Protection and Control, 2022, 50(18): 50-60.
- [10] 曹敬, 金玉龙, 郑涛, 等. 计及分布式电源集群不确定性的配电网分散鲁棒电压控制[J]. 电力系统保护与控制, 2023, 51(22): 155-166.
CAO Jing, JIN Yulong, ZHENG Tao, et al. A decentralized robust voltage control method for distribution networks considering the uncertainty of distributed generation clusters[J]. Power System Protection and Control, 2023, 51(22): 155-166.
- [11] 陈忠华, 高振宇, 陈嘉敏, 等. 考虑不确定性因素的综合能源系统协同规划研究[J]. 电力系统保护与控制, 2021, 49(8): 32-40.
CHEN Zhonghua, GAO Zhenyu, CHEN Jiamin, et al. Research on cooperative planning of an integrated energy system considering uncertainty[J]. Power System Protection and Control, 2021, 49(8): 32-40.
- [12] JCGAM J. Evaluation of measurement data—guide to the expression of uncertainty in measurement[J]. International Organization Standard Geneva ISBN, 2008, 50: 134.
- [13] YONEDA K, YONEZU A, HIRAKATA H, et al. Estimation of anisotropic plastic properties of engineering steels from spherical impressions[J]. International Journal of Applied Mechanics, 2010, 2(2): 355-379.
- [14] SINGH V, MOGER T, JENA D. Uncertainty handling techniques in power systems: a critical review[J]. Electric Power Systems Research, 2022, 20.
- [15] HU Huan, DU Xiaoshi, XU Chen, et al. Risk assessment of cascading failure in power systems based on uncertainty theory[C]// 2011 IEEE Power and Energy Society General Meeting, July 24-28, 2011, Detroit, MI, USA: 1-5.
- [16] DASHTAKI A A, HAKIMI S M, HASANKHANI A, et al. Optimal management algorithm of microgrid connected to the distribution network considering renewable energy system uncertainties[J]. International Journal of Electrical Power & Energy Systems, 2023, 145.
- [17] 孙惠娟, 巩磊, 彭春华, 等. 考虑风光水多重不确定性置信风险的多目标动态分解优化调度[J]. 电网技术, 2022, 46(9): 3416-3425.
SUN Huijuan, GONG Lei, PENG Chunhua, et al. Multi-objective dynamic decomposition optimal dispatch considering wind-photovoltaic-hydro multiple uncertainty confidence risk[J]. Power System Technology, 2022, 46(9): 3416-3425.
- [18] 温泽之. 计及风电置信风险的源网协调优化调度研究[D]. 南昌: 华东交通大学, 2020.
WEN Zezhi. Source-grid coordination multi-objective optimal scheduling considering the confidence risk of wind power[D]. Nanchang: East China Jiaotong University, 2020.
- [19] 巩磊. 计及风光水电置信风险的动态分解优化调度研究[D]. 南昌: 华东交通大学, 2022.
GONG Lei. Research on dynamic decomposition optimal dispatch considering the confidence risk of wind power photovoltaic hydropower[D]. Nanchang: East China Jiaotong University, 2020.
- [20] 刘蓉晖, 王乐凯, 孙改平, 等. 考虑不确定性的风-光-储合作联盟参与含需求响应的主辅联合市场的竞价交易模型[J]. 电力系统保护与控制, 2023, 51(11): 96-107.

- LIU Ronghui, WANG Lekai, SUN Gaiping, et al. Bidding transaction model of wind-solar-storage cooperative alliance participating in the main and auxiliary joint market with demand response considering uncertainty[J]. *Power System Protection and Control*, 2023, 51(11): 96-107.
- [21] 成龙, 李国庆, 王翀, 等. 考虑预测误差不确定性和功率互济的配电网直流合环重构[J]. *电力系统保护与控制*, 2024, 52(24): 97-108.
- CHENG Long, LI Guoqing, WANG Chong, et al. DC loop-closed reconfiguration for distribution networks considering prediction error uncertainty and power complementarity[J]. *Power System Protection and Control*, 2024, 52(24): 97-108.
- [22] 董晓翀, 孙英云, 蒲天骄, 等. 一种基于 Wasserstein 距离及有效性指标的最优场景约简方法[J]. *中国电机工程学报*, 2019, 39(16): 4650-4658.
- DONG Xiaochong, SUN Yingyun, PU Tianjiao, et al. An optimal scenario reduction method based on Wasserstein distance and validity index[J]. *Proceedings of the CSEE*, 2019, 39(16): 4650-4658.
- [23] 董晓翀. 基于数据驱动的可再生能源场景生成与约简方法研究[D]. 北京: 华北电力大学, 2020.
- DONG Xiaochong. Renewable energy scenario generation and reduction based on data-driven method[D]. Beijing: North China Electric Power University, 2020.
- [24] HUNT-SMITH N T, MELNITCHOUK W, RINGER F, et al. Accelerating Markov chain Monte Carlo sampling with diffusion models[J]. *Computer Physics Communications*, 2024, 296.
- [25] 李洪裕, 董晓翀, 王新迎, 等. 考虑数据隐私保护的可再生能源场景生成框架[J]. *电网技术*, 2023, 47(9): 3690-3697.
- LI Hongyu, DONG Xiaochong, WANG Xinying, et al. Framework for renewable energy scenario generation considering data privacy-preservation[J]. *Power System Technology*, 2023, 47(9): 3690-3697.
- [26] HALIDIAS N. Asymptotic theorems for discrete Markov chains[J]. *Asian Journal of Probability and Statistics*, 2024, 26(2): 1-17.
- [27] 吴艳梅, 陈红坤, 陈磊, 等. 基于改进 MMD-GAN 的可再生能源随机场景生成[J]. *电力系统保护与控制*, 2024, 52(19): 85-96.
- WU Yanmei, CHEN Hongkun, CHEN Lei, et al. Stochastic scenario generation for renewable energy based on improved MMD-GAN[J]. *Power System Protection and Control*, 2024, 52(19): 85-96.
- [28] SHI Yunfei, WANG Bin, YU Yanwei, et al. Robust anomaly detection for multivariate time series through temporal GCNs and attention-based VAE[J]. *Knowledge-Based Systems*, 2023, 275.
- [29] WANG Qingfeng, ZHOU Xuehai, WANG Chao, et al. WGAN-based synthetic minority over-sampling technique: Improving semantic fine-grained classification for lung nodules in CT images[J]. *IEEE Access*, 2019, 7: 18450-18463.
- [30] 叶晨, 关玮. 生成式对抗网络的应用综述[J]. *同济大学学报(自然科学版)*, 2020, 48(4): 591-601.
- YE Chen, GUAN Wei. A review of application of generative adversarial networks[J]. *Journal of Tongji University (Natural Science)*, 2020, 48(4): 591-601.
- [31] ZHANG He, SINDAGI V, PATEL V M. Image de-raining using a conditional generative adversarial network[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, 30(11): 3943-3956.
- [32] 唐贤伦, 杜一铭, 刘雨微, 等. 基于条件深度卷积生成对抗网络的图像识别方法[J]. *自动化学报*, 2018, 44(5): 855-864.
- TANG Xianlun, DU Yiming, LIU Yuwei, et al. Image recognition with conditional deep convolutional generative adversarial networks[J]. *Acta Automatica Sinica*, 2018, 44(5): 855-864.
- [33] 李鑫, 焦斌, 林蔚天. 基于条件信息卷积生成对抗网络的图像识别[J]. *计算机工程与应用*, 2020, 56(14): 191-198.
- LI Xin, JIAO Bin, LIN Weitian. Image recognition based on C-Info-DCGAN[J]. *Computer Engineering and Applications*, 2020, 56(14): 191-198.
- [34] CHEN Yize, WANG Yishen, KIRSCHEN D, et al. Model-free renewable scenario generation using generative adversarial networks[J]. *IEEE Transactions on Power Systems*, 2018, 33(3): 3265-3275.
- [35] LIU Bingqi, LÜ Jiwei. Application of an improved DCGAN for image generation[J]. *Mobile Information Systems*, 2022, 2022(1).
- [36] NIU Zijian, YU Ke, WU Xiaofei. LSTM-based VAE-GAN for time-series anomaly detection[J]. *Sensors*, 2020, 20(13): 37-38.
- [37] 李丹, 王奇, 缪书唯, 等. 基于张量 SOM 和 VAE 的多风电时空功率日场景生成[J]. *可再生能源*, 2022, 40(12): 1658-1665.
- LI Dan, WANG Qi, MIAO Shuwei, et al. A daily scenario generation for spatio-temporal power of multi-wind power based on tensor SOM and VAE[J]. *Renewable Energy Resources*, 2022, 40(12): 1658-1665.
- [38] 丁明, 解蛟龙, 刘新宇, 等. 面向风电接纳能力评价的风资源/负荷典型场景集生成方法与应用[J]. *中国电机*

- 工程学报, 2016, 36(15): 4064-4072.
- DING Ming, XIE Jiaolong, LIU Xinyu, et al. The generation method and application of wind resources/ load typical scenario set for evaluation of wind power grid integration[J]. Proceedings of the CSEE, 2016, 36(15): 4064-4072.
- [39] PINSON P, MADSEN H, NIELSEN H A, et al. From probabilistic forecasts to statistical scenarios of short-term wind power production[J]. Wind Energy, 2009, 12(1): 51-62.
- [40] FU Xueqian, GUO Qinglai, SUN Hongbin, et al. Typical scenario set generation algorithm for an integrated energy system based on the Wasserstein distance metric[J]. Energy (Oxford), 2017, 135: 153-170.
- [41] 雷宇, 杨明, 韩学山. 基于场景分析的含风电系统机组组合的两阶段随机优化[J]. 电力系统保护与控制, 2012, 40(23): 58-67.
- LEI Yu, YANG Ming, HAN Xueshan. A two-stage stochastic optimization of unit commitment considering wind power based on scenario analysis[J]. Power System Protection and Control, 2012, 40(23): 58-67.
- [42] 邵郁国, 赵洁, 方俊钧, 等. 基于运行层面相关性场景的含风机配电网多目标无功优化[J]. 电网技术, 2018, 42(8): 2528-2535.
- SHAO Youguo, ZHAO Jie, FANG Junjun, et al. Multi-objective reactive power optimization of distribution network with wind turbines based on correlated scenario at operation level[J]. Power System Technology, 2018, 42(8): 2528-2535.
- [43] 王玲玲, 王昕, 郑益慧, 等. 计及多个风电机组出力相关性的配电网无功优化[J]. 电网技术, 2017, 41(11): 3463-3469.
- WANG Lingling, WANG Xin, ZHENG Yihui, et al. Reactive power optimization of distribution network considering output correlation of multiple wind turbines[J]. Power System Technology, 2017, 41(11): 3463-3469.
- [44] STURT A, STRABC G. Efficient stochastic scheduling for simulation of wind-integrated power systems[J]. IEEE Transactions on Power Systems, 2012, 27(1): 323-334.
- [45] 于龙泽, 肖白, 孙立国. 风光出力场景生成的条件深度卷积生成对抗网络方法[J]. 东北电力大学学报, 2021, 41(6): 90-99.
- YU Longze, XIAO Bai, SUN Ligu. Conditional depth convolution generation of confrontation network method for scenery output scenario generation[J]. Journal of Northeast Dianli University, 2021, 41(6): 90-99.
- [46] 肖白, 于龙泽, 刘洪波, 等. 基于生成虚拟净负荷的多能源电力系统日前优化调度[J]. 中国电机工程学报, 2021, 41(21): 7237-7248.
- XIAO Bai, YU Longze, LIU Hongbo, et al. Day ahead optimal dispatch of multi-energy power system based on generating virtual net load[J]. Proceedings of the CSEE, 2021, 41(21): 7237-7248.
- [47] 李湃, 管晓宏, 吴江. 基于大气动力模型的多风电场出力场景生成方法[J]. 中国电机工程学报, 2015, 35(18): 4581-4590.
- LI Pai, GUAN Xiaohong, WU Jiang. Wind power scenario generation for multiple wind farms based on atmospheric dynamic model[J]. Proceedings of the CSEE, 2015, 35(18): 4581-4590.
- [48] 季峰, 蔡兴国, 王俊. 基于混合 Copula 函数的风电功率相关性分析[J]. 电力系统自动化, 2014, 38(2): 1-5, 32.
- JI Feng, CAI Xingguo, WANG Jun. Wind power correlation analysis based on hybrid Copula[J]. Automation of Electric Power Systems, 2014, 38(2): 1-5, 32.
- [49] 吴卫兵, 周松林, 邢时超. 基于 Copula 理论及时序重构技术的相关性风速模拟[J]. 电力系统及其自动化学报, 2019, 31(8): 66-72.
- WU Weibing, ZHOU Songlin, XING Shichao. Correlative wind speed simulation based on Copula theory and time series reconstruction technology[J]. Proceedings of the CSEE, 2019, 31(8): 66-72.
- [50] 董雷, 孟天骄, 陈乃仕, 等. 采用马尔可夫链—多场景技术的交直流主动配电网优化调度[J]. 电力系统自动化, 2018, 42(5): 147-153.
- DONG Lei, MENG Tianjiao, CHEN Naishi, et al. Optimized scheduling of AC/DC hybrid active distribution network using Markov chains and multiple scenarios technique[J]. Automation of Electric Power Systems, 2018, 42(5): 147-153.
- [51] DE GIORGI M G, FICARELLA A, TARANTINO M. Error analysis of short term wind power prediction models[J]. Applied Energy, 2011, 88(4): 1298-1311.
- [52] 董文略, 王群, 杨莉. 含风光水的虚拟电厂与供电公司协调调度模型[J]. 电力系统自动化, 2015, 39(9): 75-81, 207.
- DONG Wenlüe, WANG Qun, YANG Li. A coordinated dispatching model for a distribution utility and virtual power plants with wind/photovoltaic/hydro generators[J]. Automation of Electric Power Systems, 2015, 39(9): 75-81, 207.
- [53] 黎静华, 文劲宇, 程时杰, 等. 考虑多风电场出力 Copula 相关关系的场景生成方法[J]. 中国电机工程学报, 2013, 33(16): 30-36.
- LI Jinghua, WEN Jinyu, CHENG Shijie, et al. A scene generation method considering copula correlation relationship of multi-wind farms power[J]. Proceedings of

- the CSEE, 2013, 33(16): 30-36.
- [54] 张晓辉, 闫柯柯, 卢志刚, 等. 基于场景概率的含风电系统多目标低碳经济调度[J]. 电网技术, 2014, 38(7): 1835-1841.
ZHANG Xiaohui, YAN Keke, LU Zhigang, et al. Scenario probability based multi-objective optimized low-carbon economic dispatching for power grid integrated with wind farms[J]. Power System Technology, 2014, 38(7): 1835-1841.
- [55] SHARMA K C, JAIN P, BHAKAR R. Wind power scenario generation and reduction in stochastic programming framework[J]. Electric Power Components and Systems, 2013, 41(3): 271-285.
- [56] 郭顺宁, 马雪, 杨帆, 等. 基于最优 Copula 相关性分析的短期风速预测方法[J]. 电网与清洁能源, 2024, 40(2): 63-72.
GUO Shunning, MA Xue, YANG Fan, et al. A Short-term wind speed prediction method based on optimal copula correlation analysis[J]. Power System and Clean Energy, 2024, 40(2): 63-72.
- [57] 徐箭, 洪敏, 孙元章, 等. 基于经验 Copula 函数的多风电场出力动态场景生成方法及其在机组组合中的应用[J]. 电力自动化设备, 2017, 37(8): 81-89.
XU Jian, HONG Min, SUN Yuanzhang, et al. Dynamic scenario generation based on empirical Copula function for outputs of multiple wind farms and its application in unit commitment[J]. Electric Power Automation Equipment, 2017, 37(8): 81-89.
- [58] 白凯峰, 顾洁, 彭虹桥, 等. 融合风光出力场景生成的多能互补微网系统优化配置[J]. 电力系统自动化, 2018, 42(15): 133-141.
BAI Kaifeng, GU Jie, PENG Hongqiao, et al. Optimal allocation for multi-energy complementary microgrid based on scenario generation of wind power and photovoltaic output[J]. Automation of Electric Power Systems, 2018, 42(15): 133-141.
- [59] 林鹏, 赵书强, 谢宇琪, 等. 基于实测数据的风电功率曲线建模及不确定估计[J]. 电力自动化设备, 2015, 35(4): 90-95.
LIN Peng, ZHAO Shuqiang, XIE Yuqi, et al. Wind power curve modeling based on measured data and uncertainty estimation[J]. Electric Power Automation Equipment, 2015, 35(4): 90-95.
- [60] 于晗, 钟志勇, 黄杰波, 等. 采用拉丁超立方采样的电力系统概率潮流计算方法[J]. 电力系统自动化, 2009, 33(21): 32-35, 81.
YU Han, ZHONG Zhiyong, HUANG Jiebo, et al. A probabilistic load flow calculation method with latin hypercube sampling[J]. Automation of Electric Power Systems, 2009, 33(21): 32-35, 81.
- [61] 邹云阳, 杨莉. 基于经典场景集的风光水虚拟电厂协同调度模型[J]. 电网技术, 2015, 39(7): 1855-1859.
ZOU Yunyang, YANG Li. Synergetic dispatch models of a wind/PV/hydro virtual power plant based on representative scenario set[J]. Power System Technology, 2015, 39(7): 1855-1859.
- [62] 陈碧云, 闭晚霞, 李欣桐, 等. 考虑风-光-荷联合时序场景的分布式电源接入容量规划策略[J]. 电网技术, 2018, 42(3): 755-761.
CHEN Biyun, BI Wanxia, LI Xintong, et al. Capacity planning strategies for distributed generation considering wind-photovoltaic-load joint time sequential scenarios[J]. Power System Technology, 2018, 42(3): 755-761.
- [63] DVORKIN Y, WANG Yishen, PANDZIC H, et al. Comparison of scenario reduction techniques for the stochastic unit commitment[C]// 2014 IEEE PES General Meeting | Conference & Exposition, July 27-31, 2014, National Harbor, MD, USA.
- [64] LI Zhuangzhi, LI Zukui. Linear programming-based scenario reduction using transportation distance[J]. Computers & Chemical Engineering, 2016, 88: 50-58.
- [65] 孟安波, 林艺城, 殷豪. 计及不确定性因素的家庭并网风-光-蓄协同经济调度优化方法[J]. 电网技术, 2018, 42(1): 162-173.
MENG Anbo, LIN Yicheng, YIN Hao. Synergetic scheduling optimization method of grid-connected home wind-solar-storage system considering uncertainty factors[J]. Power System Technology, 2018, 42(1): 162-173.
- [66] 宋易阳, 李存斌, 祁之强. 基于云模型和模糊聚类的电力负荷模式提取方法[J]. 电网技术, 2014, 38(12): 3378-3383.
SONG Yiyang, LI Cunbin, QI Zhiqiang. Extraction of power load patterns based on cloud model and fuzzy clustering[J]. Power System Technology, 2014, 38(12): 3378-3383.
- [67] LI Jinghua, LAN Fei, WEI Hua. A scenario optimal reduction method for wind power time series[J]. IEEE Transactions on Power Systems, 2016, 31(2): 1657-1658.
- [68] 王守相, 陈海文, 李小平, 等. 风电和光伏随机场景生成的条件变分自动编码器方法[J]. 电网技术, 2018, 42(6): 1860-1867.
WANG Shouxiang, CHEN Haiwen, LI Xiaoping, et al. Conditional variational automatic encoder method for stochastic scenario generation of wind power and photovoltaic system[J]. Power System Technology, 2018, 42(6): 1860-1867.

- [69] 董晓翀, 孙英云, 蒲天骄. 基于条件生成对抗网络的可再生能源日前场景生成方法[J]. 中国电机工程学报, 2020, 40(17): 5527-5535.
DONG Xiaochong, SUN Yingyun, PU Tianjiao. Day-ahead scenario generation of renewable energy based on conditional GAN[J]. Proceedings of the CSEE, 2020, 40(17): 5527-5535.
- [70] 王宇昊, 刘海涛, 朱康凯, 等. 基于 SA/WGAN 的新能源场景生成方法[J]. 电气传动, 2024, 54(6): 45-53.
WANG Yuhao, LIU Haitao, ZHU Kangkai, et al. New energy scenario generation based on SA/WGAN[J]. Electric Drive, 2024, 54(6): 45-53.
- [71] CHEN Yize, WANG Xiyu, ZHANG Baosen. An unsupervised deep learning approach for scenario forecasts[C]// 2018 POWER SYSTEMS COMPUTATION CONFERENCE (PSCC), June 11-15, 2018, Dublin, Ireland.
- [72] HU Wei, ZHANG Hongxuan, DONG Yu, et al. Short-term optimal operation of hydro-wind-solar hybrid system with improved generative adversarial networks[J]. Applied Energy, 2019, 250: 389-403.
- [73] 彭雨箏, 李晓露, 李聪利, 等. 基于残差卷积自编码的风光荷场景生成方法[J]. 电力建设, 2021, 42(8): 10-17.
PENG Yuzheng, LI Xiaolu, LI Congli, et al. Typical wind-PV-load scenario generation based on residual convolutional auto-encoders[J]. Electric Power Construction, 2021, 42(8): 10-17.
- [74] 马燕峰, 傅钰, 赵书强, 等. 基于 WGAN 风光资源场景模拟和时序生产模拟的新能源电源容量配置[J]. 电力自动化设备, 2020, 40(11): 77-84.
MA Yanfeng, FU Yu, ZHAO Shuqiang, et al. Capacity allocation of new energy source based on wind and solar resource scenario simulation using WGAN and sequential production simulation[J]. Electric Power Automation Equipment, 2020, 40(11): 77-84.
- [75] 李辉, 任洲洋, 胡博, 等. 基于时序生成对抗网络的月度风光发电功率场景分析方法[J]. 中国电机工程学报, 2022, 42(2): 537-547.
LI Hui, REN Zhouyang, HU Bo, et al. A sequential generative adversarial network based monthly scenario analysis method for wind and photovoltaic power[J]. Proceedings of the CSEE, 2022, 42(2): 537-547.
- [76] 顾洁, 刘书琪, 胡玉, 等. 基于深度卷积生成对抗网络场景生成的间歇式分布式电源优化配置[J]. 电网技术, 2021, 45(5): 1742-1749.
GU Jie, LIU Shuqi, HU Yu, et al. Optimal allocation of intermittent distributed generation based on deep convolutions generative adversarial network in scenario generation[J]. Power System Technology, 2021, 45(5): 1742-1749.
- [77] 黄越辉, 孙亚南, 李驰, 等. 基于条件生成对抗网络的多区域风电短期出力场景生成方法[J]. 电网技术, 2023, 47(1): 63-72.
HUANG Yuehui, SUN Yanan, LI Chi, et al. Constructing method of short-term output scenarios for multi-regional wind power based on conditional generative adversarial network[J]. Power System Technology, 2023, 47(1): 63-72.
- [78] 陈凡, 陈刘明, 王曼, 等. 基于改进信息最大化生成对抗网络的风光出力场景可控生成方法[J]. 电网技术, 2024, 48(4): 1477-1486.
CHEN Fan, CHEN Liuming, WANG Man, et al. Controllable scenario generation method for wind power and photovoltaic output based on improved InfoGAN[J]. Power System Technology, 2024, 48(4): 1477-1486.
- [79] LIANG Junkai, TANG Wenyan. Sequence generative adversarial networks for wind power scenario generation[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(1): 110-118.
- [80] LI Yang, LI Jiazheng, WANG Yi. Privacy-preserving spatiotemporal scenario generation of renewable energies: a federated deep generative learning approach[J]. IEEE Transactions on Industrial Informatics, 2022, 18(4): 2310-2320.
- [81] REN Juan, YU Zhongping, GAO Guiliang, et al. A CNN-LSTM-LightGBM based short-term wind power prediction method based on attention mechanism[J]. Energy Reports, 2022, 8: 437-443.
- [82] 张帅, 刘文霞, 万海洋, 等. 基于改进条件生成对抗网络的可控场景生成方法[J]. 电力自动化设备, 2024, 44(6): 9-17.
ZHANG Shuai, LIU Wenxia, WAN Haiyang, et al. Controllable scenario generation method based on improved conditional generative adversarial network[J]. Electric Power Automation Equipment, 2024, 44(6): 9-17.
- [83] HUANG Sheng, YAN Chang, QU Yingpeng. Deep learning model-transformer based wind power forecasting approach[J]. Frontiers in Energy Research, 2023, 10.

收稿日期: 2024-09-24; 修回日期: 2025-01-20

作者简介:

李夫刚(1995—), 男, 博士研究生, 研究方向为清洁能源消纳及电力市场; E-mail: lifg1995@163.com

李夫海(1993—), 男, 通信作者, 工程师, 研究方向为电力系统规划。E-mail: lfh_cll@163.com

(编辑 许威)